

# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

## VYLEPŠENÍ OBRAZU Z ULTRAZVUKU PRO VIZUÁLNÍ DIAGNOSTIKU

DIPLOMOVÁ PRÁCE  
MASTER'S THESIS

AUTOR PRÁCE  
AUTHOR

Bc. JAROMÍR VAŇHARA

BRNO 2011



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**  
**ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ**

**FACULTY OF INFORMATION TECHNOLOGY**  
**DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA**

# **VYLEPŠENÍ OBRAZU Z ULTRAZVUKU PRO VIZUÁLNÍ DIAGNOSTIKU**

VISUAL ENHANCEMENT OF ULTRASOUND IMAGES

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. JAROMÍR VAŇHARA**

**VEDOUcí PRÁCE**

SUPERVISOR

**Ing. MICHAL ŠPANĚL, Ph.D.**

BRNO 2011

## Abstrakt

Ultrazvuk je velmi častou a oblíbenou metodou lékařského vyšetření. Interpretace obrazu získaného při tomto vyšetření je ovšem netriviální a vyžaduje velkou zkušenost. Tato práce se zabývá technikami vylepšení obrazu z ultrazvuku a tedy usnadněním diagnózy. Představuje základní metody zpracování obrazu vhodné na tento typ úloh a představuje také několik pokročilých postupů. Je zde ukázán návrh aplikace, která tyto postupy spojuje a vytváří tak nástroj pro zjednodušení vizuální diagnostiky.

## Abstract

Ultrasound imaging is widely used in medical examination. However, the interpretation of images is not trivial and requires much experience. In this thesis, various techniques for enhancement of visual quality of ultrasound images are presented. Several basic and advanced methods that may simplify the visual diagnosis are described. Finally, an interactive application is designed and implemented for simple usage of presented methods.

## Klíčová slova

Ultrazvuk, zvýšení kontrastu, zpracování obrazu, Gaboruv filtr, OpenCV, QT, anizotropní difuze, SRAD, texturní klasifikace

## Keywords

Ultrasound, contrast enhancement, image processing, Gabor filter, OpenCV, anisotropic diffusion, SRAD, texture classification

## Citace

Jaromír Vaňhara: Vylepšení obrazu z ultrazvuku pro vizuální diagnostiku, diplomová práce, Brno, FIT VUT v Brně, 2011

# Vylepšení obrazu z ultrazvuku pro vizuální diagnostiku

## Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením Ing. Michala Španěla, Ph.D.

.....

Jaromír Vaňhara  
24. května 2011

## Poděkování

Chtěl bych poděkovat Ing. Michalu Španělovi, Ph.D. za vedení této práce a Ing. Janu Dvořákovi a doc. MUDr. Luboši Hrazdírovi, CSc. za odborné konzultace.

© Jaromír Vaňhara, 2011.

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

<b>1 Úvod</b>	<b>3</b>
<b>2 Ultrazvuk</b>	<b>5</b>
2.1 Typy ultrazvukového obrazu . . . . .	5
2.2 Vlastnosti ultrazvukového obrazu . . . . .	7
<b>3 Metody zpracování ultrazvukového obrazu</b>	<b>8</b>
3.1 Základní metody segmentace a úpravy obrazu . . . . .	8
3.2 Pyramidová segmentace . . . . .	10
3.3 Moving Average Hybrid FIR Filter . . . . .	11
3.4 Anizotropní difuze . . . . .	12
3.5 Gaborův flitr . . . . .	15
3.6 Mean shift . . . . .	15
<b>4 Současný stav ve zpracování ultrazvukových obrazů</b>	<b>17</b>
<b>5 Návrh řešení</b>	<b>19</b>
5.1 Metody odstranění šumu . . . . .	19
5.2 Metody vylepšení obrazu . . . . .	19
5.3 Algoritmy segmentace obrazu . . . . .	19
5.4 Klasifikace oblastí v obraze na základě textury . . . . .	20
5.5 Návrh aplikace . . . . .	24
5.6 Návrh uživatelského rozhraní . . . . .	24
<b>6 Implementace</b>	<b>25</b>
6.1 Optimalizace mean shift algoritmu . . . . .	25
6.2 Použité mean shift implementace . . . . .	25
6.3 Použité knihovny . . . . .	26
6.4 Aplikace . . . . .	26
<b>7 Výsledky</b>	<b>28</b>
7.1 Odstranění šumu . . . . .	28
7.2 Texturní analýza . . . . .	30
7.3 Testování na reálných ultrazvukových obrazech . . . . .	32
<b>8 Závěr</b>	<b>39</b>
<b>A Obsah CD</b>	<b>43</b>

<b>B Plakát</b>	<b>44</b>
<b>C Výsledky texturní klasifikace pro různé sady Gaborových filtrů</b>	<b>45</b>

# Kapitola 1

## Úvod

Ultrazvukové vyšetření (nebo též sonografie) patří mezi základní diagnostické metody v medicíně. Používá se zejména při vyšetření měkkých tkání a orgánů, plodu během těhotenství a také pro vyšetření cév. Výstupem ultrazvuku je specifický obraz. Pro lékaře je nutná velká zkušenost při interpretaci získaného snímku a následného stanovení správné diagnózy. Cílem této práce je poskytnout lékaři nástroj, který tento proces zjednoduší a zkvalitní.

V rozličných oblastech lékařských zobrazovacích technik je použití zpracování obrazu (**image processing**) standardní metodou pro zlepšení čitelnosti obrazu. Při využívání ultrazvuku se takové pokusy vyskytují, ale rozhodně nejsou běžné. Obraz z ultrazvuku je nutné zpracovávat jinými metodami než například obrazy z počítačové tomografie (CT) nebo z pozitronové emisní tomografie (PET).

Práce si dává za cíl některé z metod vhodných ke zpracování ultrazvukových obrazů nalézt, implementovat a zjistit jejich reálný přínos k vylepšení vizuální diagnostiky. S nalezenými metodami pak lze i dále experimentovat a případně navrhnout vylepšení.

V rámci práce byla také vytvořena jednoduchá aplikace. Jejím smyslem je implementované metody demonstrovat. Práce i její výstupy, kterými jsou jednotlivé algoritmy zpracování ultrazvukového obrazu, byla také konzultována s externími konzultanty. Část testování proběhla přímo i na konkrétním zdravotnickém pracovišti.

Tato technická zpráva je členěna do několika základních bloků. Po tomto úvodu následuje kapitola, která poskytuje základní informace o ultrazvuku s přihlédnutím k jeho využití v medicíně. Jsou zde popsány jednotlivé typy zobrazení a základní vlastnosti ultrazvukových snímků.

Kapitola 3 teoreticky rozebírá jednotlivé metody používané při zpracování obrazu a takové, které jsou vhodné při použití v případě ultrazvukového obrazu. Je zde v krátkosti představeno několik základních metod. Také jsou ukázány pokročilejší metody, které jsou popsány důkladněji.

Následuje kapitola 4., která rozebírá některé z metod, které se v současné době při zpracování ultrazvukových obrazů používají. Poskytuje náhled na několik základních typů metod, které se při zpracování ultrazvukových obrazů dají použít. K jednotlivým typům poskytuje i příklady konkrétních algoritmů.

Následující 5. kapitola se věnuje návrhu celého systému. Je zde popsán výběr jednotlivých metod pro zpracování ultrazvukového obrazu. Dále je načrtnut vlastní návrh aplikace a také návrh uživatelského rozhraní.

Poté následuje kapitola 6., ve které je popsána vlastní implementace. Stručně jsou popsány použité knihovny a také vlastní aplikace.

Další, 7. kapitola je věnována testování implementovaných metod. V této kapitole jsou tedy otestovány metody na odstranění šumu v umělých situacích. Také jsou zde shrnuty výsledky jednotlivých metod na reálných ultrazvukových obrazech. Kromě testovacích snímků získaných z internetu byly použity obrazy pacientů se známou diagnózou. Toto přispělo k přesnější interpretaci výsledků jednotlivých algoritmů.

Poslední, závěrečná kapitola shrnuje celou práci. Ukazuje také směr možného budoucího vývoje.



## Kapitola 2

# Ultrazvuk

V této kapitole je v krátkosti popsán ultrazvuk a jeho použití. Ultrazvukem (UZV) se myslí akustické vlnění, které má vyšší frekvenci, než je hranice slyšitelnosti lidského ucha, tedy přibližně 20kHz. Ultrazvuk tedy není, na rozdíl od zvuku, slyšitelný, ale má stejnou fyzikální podstatu a podobné vlastnosti. Je využíván v řadě oblastí. Jedná se zejména o:

- lékařství — ultrazvukové vyšetření (sonografie) měkkých tkání a orgánů, také se používá například při ultrazvukové liposukci
- echolokaci — v přírodě echolokaci využívají například delfini nebo netopýři; člověk princip echolokace použil u sonaru
- čištění ultrazvukem
- odbourávání zubního kamene
- zjištění skrytých vad materiálů (defektoskopie)

Informace, které dále následují a týkají se použití ultrazvuku v medicíně a typů ultrazvukových obrazů jsou získány z [10].

Principem ultrazvukového vyšetření je skutečnost, že různé tkáně mají rozdílnou schopnost ultrazvukové vlnění pohlcovat nebo odrážet. Takové vyšetření je neinvazivní a bezbolestné. Je využíváno při vyšetření měkkých tkání, a to zejména vnitřních orgánů (jater, sleziny apod.), pohybového ústrojí (svaly a vazy), oběhového ústrojí (cévy) a také při vyšetřování v těhotenství. Při sonografii se používá většinou ultrazvuk o frekvenci 1–20 MHz. Příklad obrazu z ultrazvukového vyšetření je na obr. 2.1.

### 2.1 Typy ultrazvukového obrazu

Podle způsobu zobrazení se rozlišuje několik typů obrazu:

#### Zobrazení A

Jedná se o nejjednodušší způsob zobrazení. Je to sled výchylek časové osy osciloskopu, kde poloha výchylky ukazuje místo odrazu a amplituda značí množství odražené energie. Název vychází z anglického **Amplitude**.

## Zobrazení B

Zobrazení B vychází z anglického **Brightness**. Jedná se o předchůdce klasického zobrazení, jak si ho představí většina lidí. Obraz je statický a vzniká pomalým posunem sondy nad vyšetřovanou oblastí. Množství odražené energie je vyjádřené jasem v daném místě.

Dnes se zobrazení B využívá jenom v podobě tzv. zobrazení B - Dynamického typu. Jedná o dvourozměrný obraz měkkých tkání. Získá se sérií paprsků v sondě. Poloha a tvar paprsků určuje výslednou podobu obrazu. Velikost odraženého signálu je znázorněna v rozsahu stupňů šedi (zpravidla 128 nebo 256 stupňů). Tímto typem se zabývá i tato práce.

## Zobrazení (T)M


Jednorozměrné zobrazení sloužící ke sledování pohybu objektů. Název vznikl ze slov **Time motion**. Využívá se zejména v kardiologii, pro zobrazení pohybů srdeční chlopně apod. Při zachycení pohybu A-obrazem se získají hranice pohybu, které se zobrazí jako (T)M obraz.

## 3D zobrazení

Velkou popularitu v poslední době získává i 3D zobrazení [11]. Většinou se získává postupným skládáním dvourozměrných obrazů. V počátcích používání 3D zobrazení byl na klasickou sondu připojen malý motorek, který zajišťoval standardní polohu a rychlost posunu. V současné době byly vyvinuty jiné způsoby zachycení polohy a rychlosti pohybu sondy, např. gyroskopické nebo magnetické snímače. Současné přístroje navíc často dokáží zobrazovat 3D ultrazvukový obraz v reálném čase. Tomuto zobrazení se vžil název 4D.



Obrázek 2.1: Příklad obrazu z ultrazvukového vyšetření, zobrazující játra s rakovinnými lézemi. Obraz je převzatý z [4].



Obrázek 2.2: Artefakt v ultrazvukovém obraze kolen. Červeně je vyznačen povrch kosti. Pod ním se nachází ultrazvukový stín, a tak by v té oblasti neměly být žádné odezvy.

### Metody zobrazení průtoku krve

Při ultrazvuku je možné také měřit rychlost průtoku krve. Je při tom využit Dopplerův efekt. Měří se jednak časový a frekvenční průběh odrazových vln a lze tedy zobrazit místo i rychlost průtoku krve. Většinou je výsledek zobrazen jako barevná informace na UZV obraze typu B.

## 2.2 Vlastnosti ultrazvukového obrazu

Dynamický B-obraz, kterým se práce zabývá, má velmi specifické vlastnosti. Je tvořen sérií ultrazvukových vln, které se podle typu tkáně šíří různou rychlostí a odrážejí se zpět do sondy. Z toho plyne několik skutečností, které ovlivňují podobu snímku.

Jedním z nich je specifický zrnitý typ šumu, tzv. **speckle noise**. Jedná se o multiplikativní šum, který vzniká interferencí mezi původními a odraženými paprsky. Potlačením tohoto typu šumu, při zachování detailů a ostroty hran v obraze, se zabývá velké množství prací.

K ultrazvukovým snímkům patří i artefakty. Vznikají nesprávnou interpretací odražených vln, například způsobenou několikanásobným odrazem. Artefakty mají podobu například obrazu, který zrcadlově převrácený, případně světlejšího nebo tmavšího místa, než by odpovídala okolní tkáň. Mohou se také vyskytovat v místech ultrazvukového stínu apod. Tato situace je vidět na obr. 2.2. Pod červeně vyznačeným povrchem kosti je ultrazvukový stín, ve které by se neměly nacházet žádné odezvy.

## Kapitola 3

# Metody zpracování ultrazvukového obrazu

V této kapitole jsou obecně popsány jednotlivé metody, které se používají při zpracování obrazu s přihlédnutím k použití u snímků z ultrazvuku. Na začátku jsou ve stručnosti představeny základní metody, vhodné zejména ke předzpracování původního obrazu nebo dodatečné úpravě výsledného obrazu.

Dále jsou v této kapitole popsány i pokročilejší metody týkající se zejména odstranění šumu a také je představena metoda klasifikace oblastí v obraze na základě textury.

### 3.1 Základní metody segmentace a úpravy obrazu

V této části jsou v krátkosti popsány základní metody úpravy a segmentace obrazu, které jsou vhodné pro zpracování obrazů z ultrazvuku. Informace z této části jsou získány z [17] a [26].

#### Prahování

Jednou ze základních metod segmentace obrazu je prahování (**threshold**) [17]. Jedná se o operaci, při níž se upravují hodnoty bodů daného obrazu podle následujícího vztahu:

$$f(c) = \begin{cases} A, & \text{pokud } c < \text{práh} \\ B, & \text{pokud } c \geq \text{práh} \end{cases}, \quad (3.1)$$

kde  $c$  značí intenzitu nebo barvu daného bodu,  $\text{práh}$  je hodnota, která se porovnává s původní hodnotou.  $A, B$  jsou hodnoty nového bodu.

#### Lineární konvoluční filtr (2D FIR filtr)

Lineární konvoluční filtr [26] je matematická funkce nad obrazem. Je popsán konvolučním vzorem (jádreem). Jednotlivé body výsledného obrazu se dají získat z následující rovnice:

$$y_{(i,j)} = \sum_{ii=-\frac{s}{2}}^{\frac{s}{2}} \sum_{jj=-\frac{s}{2}}^{\frac{s}{2}} x_{(i+ii,j+jj)} \cdot k_{i+ii,j+jj}, \quad (3.2)$$

kde  $y_{(i,j)}$  je bod výsledného obrazu,  $x_{(i,j)}$  je bod vstupního obrazu a  $k$  je konvoluční jádro ve tvaru čtverce o straně velikosti  $s$ . Filtr vychází z klasické konvoluce, kterou ovšem

můžeme nahradit danou sumou, protože jsou obrazy diskrétní. Konvoluční vzor většinou bývá velikosti 3x3, 5x5 nebo 7x7 pixelů, ale nemusí tak být vždy.

Linearita u filtru znamená, že filtr vyhovuje principu superpozice. To znamená, že odezva systému tvořeného lineárním filtrem je součtem dvou nebo více signálů. V našem případě se tedy jedná o součet původního signálu se signálem filtru.

Lineární filtrování se používá zejména při úpravách obrazů, jako je například doostření, rozostření nebo například zvýraznění hran.

Jedním z významných konvolučních jader je takové, jehož prvky jsou získány pomocí Gaussovske funkce (rovnice 3.3).

$$G_{x,y} = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.3)$$

Filtru s tímto konvolučním jádrem se říká **gaussovský filtr** a používá se pro rozostření obrazu a odstranění Gaussovského šumu.

### Mediánový filtr

Na rozdíl od konvolučního filtru je mediánový filtr [26] nelineární. Mediánový filtr se dá vyjádřit následující rovnicí (zde pro okolí 3x3, obecně může být i jiné):

$$y_{(i,j)} = \text{median}(x_{(i-1,j-1)}, x_{(i-1,j)}, \dots, x_{(i+1,j)}, x_{(i-1,j+1)}) \quad (3.4)$$

Funkce *median* vrací střední hodnotu v daném souboru prvků. Mediánový filtr se používá zejména při odstranění šumu.

### Unsharp mask

Unsharp mask (neostrá maska, většinou se termín nepřekládá) je další nelineární filtr. Používá se pro doostření obrazu. Jeho principem je získání nízkofrekvenčního (rozmazaného, odtud plyne název) obrazu a jeho odečtením od původního obrazu. Nízkofrekvenční obraz se získá pomocí nízkofrekvenčního filtru, zpravidla Gaussovým filtrem. Filtr popisuje následující rovnice:

$$y_{(i,j)} = g_{(i,j)} + (x_{(i,j)} - g_{(i,j)}) \cdot \gamma, \quad (3.5)$$

kde  $y_{(i,j)}$  je bod výsledného obrazu,  $x_{(i,j)}$  je bod zdrojového obrazu a  $g_{(i,j)}$  je bod nízkofrekvenčního obrazu. Parametr  $\gamma$  určuje množství, o kolik je obraz doostřen. Pokud  $\gamma = 1$  je výsledný obraz shodný se zdrojovým a pokud  $\gamma < 1$  je výsledný obraz místo doostření rozmazán.


### Histogram a jeho ekvalizace

Histogram je graf absolutní četnosti hodnot jasů jednotlivých pixelů v obraze. Je tedy dobrou pomůckou při popisu obrazu.

V případě málo kontrastního obrazu většina hodnot v histogramu leží pouze v omezeném prostoru. Kontrast lze tedy zvýšit, pokud je obraz upraven tak, že hodnoty jsou rozprostřeny po celé šířce histogramu. Takové úpravě se pak říká ekvalizace histogramu [17].

V případě šedotónového obrazu lze vypočítat pravděpodobnost  $p_x(i)$ , že daný bod  $x$  má jasovou hodnotu  $i$  ze vzorce 3.6.

$$p_x(i) = \frac{n_i}{n} \quad (3.6)$$



Obrázek 3.1: Původní obraz nahoře má špatný kontrast. To je patrné i z jeho histogramu. Upravený obraz s ekvalizovaným histogramem má kontrast o hodně vyšší. Převzato z [22].

Hodnota  $n$  je celkový počet bodů v obraze a  $n_i$  je počet bodů v obraze s jasnem  $i$ . Dále je možné vypočítat distribuční funkci  $F$ :

$$F(x_i) = \sum_{j=0}^i p(x_j) \quad (3.7)$$

Nový obraz s ekvalizovaným histogramem se pak získá takto (předpokládá obraz s intenzitami v rozsahu  $\langle 0, 255 \rangle$ ):

$$y = F(x) \cdot 255 \quad (3.8)$$

Příklad ekvalizace histogramu je na obr. 3.1. Je zde původní i upravený obraz společně s histogramy.

## 3.2 Pyramidová segmentace

Zajímavou metodou pro segmentaci obrazu je pyramidová segmentace [21]. Jak je z názvu patrné, metoda využívá obrazové pyramidy. To je kolekce obrazů vycházejících z původního. Velikost následujícího obrazu v pyramidě je vždy čtvrtina předchozího. Postup pro získání obrazové pyramidy z původního obrazu může vypadat například takto:

1. Vezmi obraz a rozmaž ho Gaussovým filtrem
2. Vynechej každý sudý řádek a sloupec
3. Tento obraz je aktuálním stupněm pyramidy



Obrázek 3.2: Obraz segmentovaný pomocí pyramidové segmentace s parametry  $práh_1 = 255$  a  $práh_2 = 65$ .

4. Pokud aktuální stupeň pyramidy není požadovaný, pokračuj bodem 1. s obrazem aktuálního stupně pyramidy

Jako nejvyšší stupeň pyramidy je dále označován původní obraz (největší obraz dané pyramidy) a naopak nejmenší obraz pyramidy bude nejnižší stupeň. Je zřejmé, že původní snímek musí mít výšku i šířku hodnotu dělitelnou  $2^N$ , kde  $N$  je počet stupňů pyramidy.

Každý pixel nižšího stupně tedy odpovídá čtyřem bodům obrazu vyššího stupně. Tohoto se dá využít pro segmentaci. Postup získání segmentovaného obrazu z obrazové pyramidy je následující:


1. Vezmi nejnižší stupeň pyramidy jako aktuální
2. Pro každý bod  $x_i$  aktuálního stupně ( $i$ ):
  - (a) Nalezni body odpovídající tomuto bodu na stupni  $i + 1$
  - (b) Každý nalezený bod  $y_{i+1}$  nastav na hodnotu  $x_i$  pokud  $|x_i - y_{i+1}| < práh_1$ .
  - (c) Jinak bodu  $y_{i+1}$  ponechej jeho hodnotu.
3. Sluč dva segmenty  $A, B$  (oblasti se stejnou hodnotou pixelu) na stupni  $i + 1$ , pokud  $|a - b| < práh_2$ , kde  $a$  je hodnota bodů v segmentu  $A$  a  $b$  je hodnota bodů v segmentu  $B$ .
4. Pokud  $i + 1$  není nejvyšší stupeň pyramidy, nastav aktuální stupeň pyramidy na  $i + 1$  a pokračuj bodem 2. Jinak vrať aktuální obraz.

Tento algoritmus využívá parametrů  $práh_1$  a  $práh_2$ , které ve výsledku, spolu se stupněm pyramidy, určují počet výsledných segmentů obrazu. Příklad výsledku této segmentace je na obr. 3.2.

### 3.3 Moving Average Hybrid FIR Filter

Problémem v ultrazvukových obrazech je šum. Tento filtr, představený v [16], umožňuje potlačit takovýto šum, ale zároveň co možná nejvíce zachovat ostrost obrazu. Jeho principem je použití dvou lineárních konvolučních filtrů. Tyto filtry jsou definovány rovnicemi 3.9 a 3.10.





Obrázek 3.3: Vlevo původní, značně zašuměný obraz, vpravo obraz vylepšený pomocí MAH FIR filteru.

$$h_1(i) = \frac{2(2N - 1) - 6i}{N(N + 1)} \quad (3.9)$$

$$h_2(i) = \frac{2(2N + 1) - 6i}{N(N - 1)} \quad (3.10)$$

Výstupy těchto dvou filtrů jsou následně zkombinovány s původním obrazem a to tak, že se vždy vezme medián těchto tří hodnot. Jak již bylo řečeno, filtr má velmi vhodné vlastnosti z hlediska potlačení šumu. Na rozdíl od základních metod, jako je filtrování Gaussovým nebo mediánovým filtrem, zanechává obraz poměrně ostrý. Výstup filtru je vidět na obr. 3.3.

V rozšiřujícím článku[12] na toto téma jsou popsány konstrukce dalších hybridních filtrů, vycházejících zejména z definování nových konvolučních jader pomocí polynomiálních modelů. Princip výběru prvku pomocí mediánu u těchto metod zůstává.

### 3.4 Anizotropní difuze

Také anizotropní difuze[18] patří mezi známé a používané metody odstranění šumu. Její výhodou je opět velmi dobré zachování hran v obraze. Metoda funguje iterativně, tedy potlačuje šum v postupných krocích.

Základem anizotropní difuze je parciální diferenciální rovnice daná následujícím předpisem:

$$\frac{\partial I}{\partial t} = \text{div}[c(|\nabla I|) \cdot \nabla I] \quad (3.11)$$

$$I(t = 0) = I_0 \quad (3.12)$$

$\nabla I$  je gradient obrazu  $I$  a  $\text{div}$  značí divergenční operátor.  $I_0$  značí původní obraz a funkce  $c(x)$  je tzv. difuzní koeficient. V článku autorů Perony a Malika [18] jsou navrženy dva druhy tohoto koeficientu (rovnice 3.13 a 3.14).

$$c_1(x) = \frac{1}{1 + (x/\kappa)^2} \quad (3.13)$$

$$c_2(x) = e^{-(x/\kappa)^2} \quad (3.14)$$



Parametr  $\kappa$  zde ovlivňuje velikost změny v oblasti, aby mohla být považována za hranu.

Gradientsy obrazu v jednotlivých směrech se získají lineárním filtrováním s následujícími konvolučními maskami:

$$\nabla I_n = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (3.15)$$

$$\nabla I_s = \begin{bmatrix} 0 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (3.16)$$

$$\nabla I_w = \begin{bmatrix} 0 & 0 & 0 \\ 1 & -1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (3.17)$$

$$\nabla I_e = \begin{bmatrix} 0 & 0 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & 0 \end{bmatrix} \quad (3.18)$$

Velikost gradientu  $|\nabla I|$  je pak:

$$|\nabla I| = \sqrt{\nabla I_n^2 + \nabla I_s^2 + \nabla I_e^2 + \nabla I_v^2} \quad (3.19)$$

Rozdíly mezi oběma difuzními koeficienty je možné vidět na obr. 3.4. Je patrné, že difuzní koeficient  $c_1$  (obr. 3.4b) oproti  $c_2$  (obr. 3.4c) lépe zachovává ostré hrany. Jinak jsou ve výsledných obrazech jen minimální rozdíly.

## SRAD

Anizotropní difuze se dobře vypořádává s tzv. aditivním šumem. Ultrazvukové obrazy ovšem většinou trpí odlišným typem šumu, který je nazýván jako **speckle**. Někteří autoři navrhují tedy speciální úpravy této metody vhodné pro ultrazvukové obrazy. Jedním z těchto přístupů je SRAD (**Speckle reducing anisotropic diffusion**) [25].

Základní rozdíl oproti klasickému přístupu zde spočívá v použití modifikovaného difuzního koeficientu  $c(q)$ . Opět jsou zde představeny dvě možnosti (rovnice 3.20 a 3.21).


$$c_1(q) = \frac{1}{1 + \frac{q^2(x,y;t) - q_0^2(t)}{q_0^2(t) \cdot (1 + q_0^2(t))}} \quad (3.20)$$

$$c_2(q) = e^{-\frac{q^2(x,y;t) - q_0^2(t)}{q_0^2(t) \cdot (1 + q_0^2(t))}} \quad (3.21)$$


V této rovnici jako hranový detektor, který zohledňuje šum typu **speckle**, figuruje funkce  $q$  (rovnice 3.22). Funkce  $q_0$  definuje, podobně jako parametr  $\kappa$  při klasickém přístupu, velikost změny v oblasti, aby to bylo považováno za hranu.

$$q(x, y; t) = \sqrt{\frac{\frac{1}{2} \left( \frac{|\nabla I|}{I} \right)^2 - \frac{1}{16} \left( \frac{\nabla^2 I}{I} \right)^2}{\left( 1 + \frac{1}{4} \frac{\nabla^2 I}{I} \right)^2}} \quad (3.22)$$


Člen  $\nabla^2 I$  v této rovnici značí druhou derivaci obrazu. Získá se pomocí diskrétního Laplaceova operátoru. Tento člen se získá za pomoci lineární filtrace s následujícím jádrem:




(a) Původní obraz




(b) AD  $c_1$



(c) AD  $c_2$



(d) SRAD  $c_1$



(e) SRAD  $c_2$

Obrázek 3.4: Ukázka anizotropní difuze (AD) a její varianty SRAD. Je zde srovnání obou difuzních koeficientů  $c_1$  a  $c_2$  (pro AD rovnice 3.13 a 3.14 a pro SRAD rovnice 3.20 a 3.21).

$$\nabla^2 I = \begin{bmatrix} 0 & \frac{1}{4} & 0 \\ \frac{1}{4} & -1 & \frac{1}{4} \\ 0 & \frac{1}{4} & 0 \end{bmatrix} \quad (3.23)$$

Rozdíl mezi anizotropní difuzí a SRAD je vidět na obr. 3.4. Na obr. 3.4d je použita metoda SRAD s koeficientem  $c_1$ . Je zde vidět větší odstranění šumu typu **speckle** oproti druhému difuznímu koeficientu (obr. 3.4e).

### 3.5 Gaborův filtr

Gaborův filtr je známý filtr, který se používá k různým metodám zpracování obrazu, jako je detekce hran, popis textur a podobně. Je pojmenován po britském matematikovi maďarského původu Dennisi Gaborovi (1900–1979). Výhodou tohoto filtru je, že se dá jednoduše přizpůsobit v měřítku, prostorové orientaci a frekvenci. Následující rovnice popisují Gaborovskou funkci, která je základem filtru. Jelikož se jedná o funkci komplexní, je zde výpočet reálné  $f_{re}$  i imaginární složky  $f_{im}$ .

$$f_{re}(x, y) = e^{\frac{-(x'^2 + \gamma^2 y'^2)}{2\sigma^2}} \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (3.24)$$

$$f_{im}(x, y) = e^{\frac{-(x'^2 + \gamma^2 y'^2)}{2\sigma^2}} \sin\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (3.25)$$

$$x' = x \cos \theta + y \sin \theta \quad (3.26)$$

$$y' = -x \sin \theta + y \cos \theta, \quad (3.27)$$

kde  $\lambda$  určuje vlnovou délku funkce,  $\theta$  definuje natočení filtru,  $\varphi$  je fázový posun,  $\sigma$  určuje Gaussovskou obálku a tím pádem velikost jádra filtru a  $\gamma$  ovlivňuje poměr šířky a délky jádra filtru.

Z reálné a imaginární odezvy lze také spočítat velikost (magnitudu):

$$f_{mag}(x, y) = \sqrt{f_{re}(x, y)^2 + f_{im}(x, y)^2} \quad (3.28)$$


Gaborův filtr je možné využít k popisu textury. Pokud obraz filtrujeme sadou Gaborových filtrů o různých, vhodně zvolených frekvencích a s různým natočením, oblast obrazu se stejnou nebo podobnou texturou dá stejnou odpověď. Toho je tedy možné využít při segmentaci obrazu. Příklady takových jader filtru s různým natočením a různou vlnovou délkou jsou na obrázku 3.5. Podrobněji je technika klasifikace oblastí v ultrazvukovém obraze na základě textury popsána v další části.

### 3.6 Mean shift

Mean shift [7] je známá metoda shlukování (angl. **clustering**), jejíž cílem je rozdělit prostor příznaků (**feature space**) na shluky. Jejím principem je předpoklad, že hustota bodů v prostoru příznaků roste směrem ke středu shluků. Výhodou této metody je, že není předem třeba znát počet shluků.

Jedná se o iterační metodu, která v každém kroku pro všechny body nalezne vektor, který směřuje do lokálního maxima hustoty bodů. Hustotu bodů v dané oblasti lze nalézt pomocí následujícího vzorce:

$$f(x) = \frac{1}{Nh^d} \sum_{i=0}^N k\left(\frac{|x - x_i|}{h}\right) \quad (3.29)$$



Obrázek 3.5: Příklady jader Gaborova filtru s různým natočením a různou frekvencí.

Funkce  $k(x)$  je jádro (**kernel**). Tato funkce musí splňovat dvě základní vlastnosti:

$$\int_{R^d} k(x) = 1 \quad (3.30)$$

$$k(x) \geq 0 \quad (3.31)$$

Velmi často používaná funkce jádra je Gaussova (rovnice 3.32). Tato funkce je využita i v této práci.

$$k(x) = e^{-\frac{x^2}{2\sigma^2}} \quad (3.32)$$

Pro každý bod se hledá vektor gradientu hustoty bodů v okolí počítaného bodu (rovnice 3.33). Tomuto vektoru se říká mean shift.

$$m(x) = \frac{\sum_{i=0}^n g\left(\frac{|x-x_i|}{h}\right)x_i}{\sum_{i=0}^n g\left(\frac{|x-x_i|}{h}\right)} - x \quad (3.33)$$

$$g(x) = -k(x) \quad (3.34)$$

Dosazením použitého Gaussova kernelu se potom získá výsledná funkce mean shift použitá v této práci:

$$m(x) = \frac{\sum_{i=0}^n e^{-\frac{|x-x_i|^2}{h^2}}x_i}{\sum_{i=0}^n e^{-\frac{|x-x_i|^2}{h^2}}} - x \quad (3.35)$$

Tímto výpočtem se získá nová pozice daného bodu. V případě, že změna oproti minulé pozici je menší než zadané  $\epsilon$ , výpočet pro daný bod končí. Nová pozice tohoto bodu je lokální maximum hustoty bodů v prostoru příznaků.

Tento výpočet je opakován pro všechny body. Ty, které dokonvergují do stejného místa pak tvoří jeden shluk.

Výpočet je ovlivněn jedním parametrem. Tím je šířka pásma (**bandwidth**) označená jako  $h$ . Tento parametr určuje velikost okna, ze kterého se určuje hustota bodů v prostoru příznaků. Tento parametr může být buď globální pro všechny body výpočtu, nebo může být různý pro každý bod a zohledňovat tím lokální charakteristiky prostoru. Je doporučováno několik různých metodik výpočtu tohoto parametru [7].

## Kapitola 4

# Současný stav ve zpracování ultrazvukových obrazů

V této části jsou popsány současné metody zpracování ultrazvukových obrazů. V této oblasti převažují metody na odstranění šumu a segmentace obrazu.


Při odstranění šumu se často používají různá rozšíření základního mediánového filtru, který byl již popsán v teoretickém úvodu. Na základě lokálních statistických parametrů obrazu je mediánový filtr upraven například v [13]. Podobný přístup je uveden v [24], kde je mediánový filtr upraven podle hodnot lokální entropie obrazu. Čím je entropie v dané části menší, tím filtr více potlačuje změny v obraze. Pokud je ovšem entropie vysoká, převládá snaha zachovat signál.

Další možností je Moving Average Hybrid FIR filter, který je podrobněji popsán v předchozí kapitole (3.3). Kombinuje použití konvoluce s mediánovým výběrem hodnot.

Porovnáním tří různých způsobů odstranění šumu ultrazvukových obrazů a navržením společného vylepšení pro tyto metody se zabývá článek [14]. Porovnávané metody jsou ADDS (**a**nisotropic **d**iffusion **d**e-speckling), HWDS (**h**omomorphic **w**avelet **d**e-speckling) a TVDS (**t**otal-**v**ariation **d**e-speckling). První algoritmus je podobný popsanému přístupu SRAD, liší se v použitém difuzním koeficientu. Metoda HWDS používá k odstranění šumu vlnkové filtry. TVDS staví na metodě totální variace a přizpůsobuje ji pro odstranění šumu v ultrazvukovém obraze. Navržená metoda zlepšení těchto algoritmů spočívá v logaritmické transformaci. Po této transformaci se z multiplikativního šumu stává šum aditivní. Ten je odstraněn výše zmíněnými algoritmy a poté je obraz převeden zpět. Tato modifikace má podle autorů velmi dobré výsledky.

V případě segmentačních metod existují například dvě, které používají Gaborův filtr různým způsobem. První [15] po použití sady Gaborových filtrů extrahuje příznaky z odezev a pomocí algoritmu shlukování jsou dále přiřazeny do jednotlivých shluků. V rámci tohoto článku jako shlukovací algoritmus použili K-means, ale je možné využít i jiné. Princip je podobný metodě, která byla implementována i v aplikaci. Podrobněji jsou jednotlivé části algoritmu popsány v části 5.4.

Druhá metoda [23] používá odezev Gaborova filtru, společně s extrakcí příznaků na základě tvaru ke trénování klasifikátoru. Používá se zde zajímavá metoda, kdy je každá prohledávaná oblast rozdělena úsečkou na dvě a ty se filtrují odděleně. V případě získání různých odezev je možné považovat tuto přímkou za hraniční mezi dvěma segmenty. V další fázi je přímkou pootočena a celý proces je zopakován. Pro názornost je tento princip zobrazen



Obrázek 4.1: Princip rozdělení oblasti, ze které se získávají vektory příznaků. V případě různých odezev na obou stranách přímky je možné přímku považovat za hranici dvou segmentů. Převzato z [23].

na obr. 4.1. V této metodě se navíc získává příznakový vektor a obraz se segmentuje na základě naučeného klasifikátoru.

Zajímavý přístup, který kombinuje odstranění šumu a segmentaci, je předveden v článku [8]. Opět je zde využita anizotropní difuze, pomocí které se obraz postupně rozmazává. Podle hodnot gradientu v daném bodě je možné rozhodnout, zda je součástí hrany a v tom případě není filtrován. Autoři představují modifikaci difuzního koeficientu. Tento koeficient způsobuje, že v oblastech, kde jsou malé hodnoty gradientu, je obraz rozmazán a naopak při vysokých hodnotách je hrana ještě zdůrazněna. Takto upravený obraz s vyznačenými hranami je možné následně využít v segmentaci. Jedná se opět o velmi podobný princip, jaký představuje metoda SRAD (popsána v kap. 3.4).

Mezi aplikace zabývající se zpracováním medicínských, mimo jiné i ultrazvukových obrazů, patří UsimagTool [1]. Aplikace je opensource a poskytuje řadu různých nástrojů a filtrů. Je postavena na knihovnách ITK, VTK a FLTK. Poslední verze aplikace je pochází z května 2009.

## Kapitola 5

# Návrh řešení

V této kapitole jsou popsány požadavky na výslednou aplikaci a její návrh. Jsou zde uvedeny vhodné metody zpracování ultrazvukového obrazu a také požadavky na grafické uživatelské rozhraní.

Jednotlivé metody byly voleny tak, aby neměly velkou výpočetní náročnost a dokázaly ultrazvukový obraz zpracovat v krátkém čase. Většina algoritmů poskytne výsledek v reálném čase, jak jsou získány obrazy přímo z ultrazvuku. Výjimkou je metoda texturní klasifikace, která výsledek poskytne relativně rychle, ale neběží v reálném čase.

### 5.1 Metody odstranění šumu

Do této kategorie metod zpracování ultrazvukového obrazu se řadí mediánový filtr a MAH FIR filtr a také anizotropní difuze a její varianta SRAD. Patří sem také různé jiné lineární konvoluční filtry s příhodnou konvoluční maskou.

Obecně jsou ultrazvukové obrazy degradovány značným šumem a pomocí těchto metod lze tento šum redukovat. Je tedy vhodné navržené filtry používat jako první fázi zpracování.


### 5.2 Metody vylepšení obrazu

Do druhé kategorie patří mimo jiné unsharp mask a také úpravy histogramu. Cílem těchto metod je ultrazvukový obraz vylepšit pro snadnější vizuální diagnostiku. Tyto algoritmy jsou důležité zejména v případě ultrazvukového obrazu se špatným kontrastem, kdy mohou zlepšit čitelnost.

### 5.3 Algoritmy segmentace obrazu

Třetí kategorii tvoří algoritmy, jejichž cílem je poskytnout informaci o jasu či struktuře jednotlivých oblastí v obraze. Do této kategorie můžeme zařadit prahování, jako nejjednodušší metodu segmentace obrazu na základě jasu. Dále sem spadá pyramidová segmentace.

Tyto metody mohou být užitečné pro odlišení různých objektů v ultrazvukovém obraze. Správné oddělení různých oblastí pak může posloužit například ke přesnějšímu změření velikosti objektů.



Obrázek 5.1: Porovnání zobrazení segmentovaného obrazu a původního obrazu, který je na základě segmentace obarven.

## Vizualizace výsledků

Důležitou součástí segmentačních metod je vhodná prezentace výsledků uživateli. Segmentační metody (z implementovaných metod se jedná o prahování a pyramidovou segmentaci) se dají vizualizovat dvěma možnými způsoby. První je zobrazení různých segmentů různým jasnem. Druhou možností je přidání barevné informace do původního obrazu.

Zde se nabízejí dvě možnosti. První možnost je obarvení obrazu jednou barvou o různé intenzitě podle segmentovaných částí. Spojení původního obrazu s obarveným se pak může provést například podle následujícího vztahu:

$$y(i, j) = 255 - \frac{((255 - x(i, j)) \cdot \alpha) \cdot ((255 - s(i, j)) \cdot c)}{255}, \quad (5.1)$$

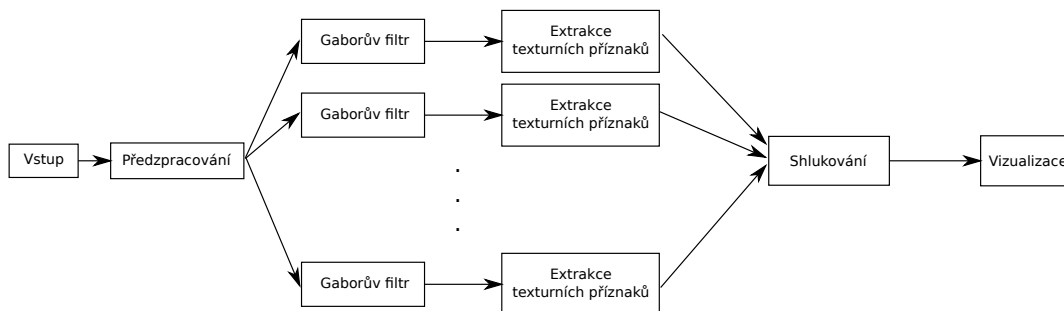
kde  $x(i, j)$  je původní obraz,  $s(i, j)$  je segmentovaný obraz,  $\alpha$  nabývá hodnot  $\langle 0, 1 \rangle$  a určuje intenzitu překrytí a  $c$  je barva, kterou se má obraz obarvit. Tato možnost je využita u základních segmentačních metod. Porovnání segmentace pomocí jasu a obarvení původního obrazu jednou barvou různé intenzity je na obr. 5.1.

## 5.4 Klasifikace oblastí v obraze na základě textury

Na odezvy ultrazvuku v určité oblasti se dá pohlížet jako na texturu. Lze tedy získat informaci o podobnosti textury v jednotlivých oblastech obrazu. Tato informace pak může pomoci odhalit řadu problémů, jako je například prorůstání rakovinných metastáz do okolní tkáně.

Celá metoda klasifikace textur v obraze je složena z několika částí. První částí je předzpracování obrazu. Dále následuje extrakce texturních příznaků, shlukovací metoda a na konec je výsledek vizualizován uživateli. Diagram této metody je na obr. 5.2. Jednotlivým částem se dále věnují následující podkapitoly.





Obrázek 5.2: Diagram texturní klasifikace.

## Předzpracování

Prvním krokem při texturní analýze je předzpracování obrazu. V tomto kroku je zejména třeba potlačit šum v obraze. K tomu se dá použít několik již představených filtrů. Na jemné odstranění šumu je použit Gaussův filtr. Pokud je šum v obraze více výrazný, je tento filtr doplněn o předzpracování pomocí anizotropní difuze, případně SRAD. MAH-FIR filtr se v tomto případě neosvědčil.

## Extrakce texturních příznaků

Je zřejmé, že příslušnost k dané textuře nelze určit jen na základě jednoho bodu. Je tedy třeba vzít určité okolí bodu a tuto oblast vhodně popsat. Výsledkem by měl být pro každou oblast vektor čísel, který texturu dané oblasti popisuje. Tento vektor se nazývá příznakový vektor.

K získání dat pro extrakci texturních příznaků je v této metodě použit Gaborův filtr. Daný obraz se filtruje sadou Gaborových filtrů o různé vlnové délce a různém natočení. Vlnové délky je třeba volit dle charakteristiky daného obrazu tak, aby jej co nejlépe popisovaly. V obrazech, které následně byly použity v testování, jsou použité vlnové délky 2px, 3px, 4px. Výběr je dán jemnou strukturou obrazu a malou velikostí.

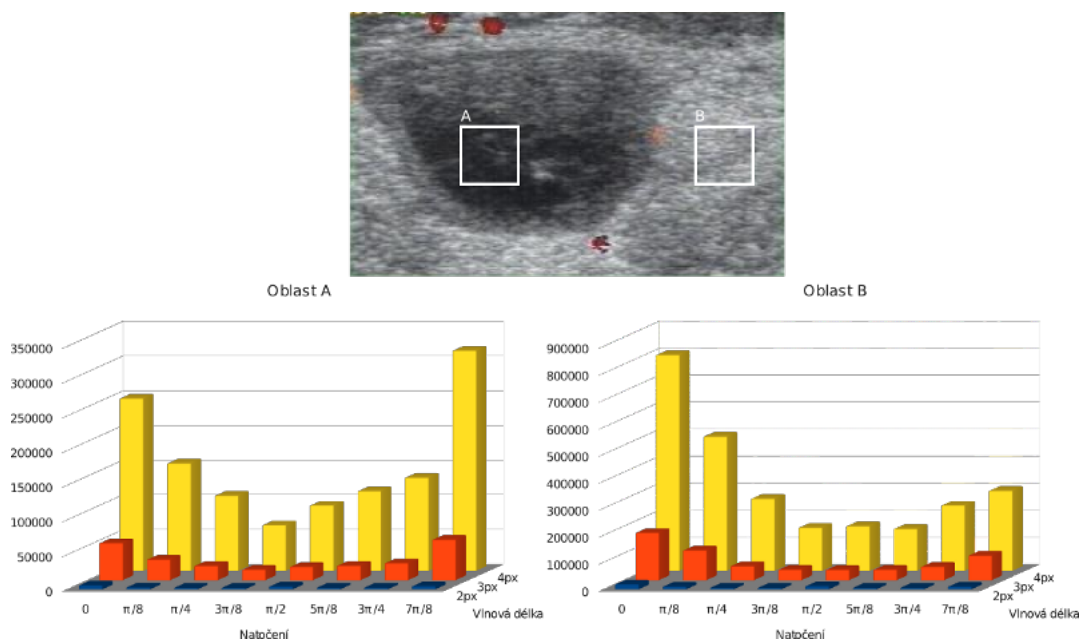
Natočení filtru bylo nakonec zvoleno v rozsahu  $\langle 0, \pi \rangle$  s krokem  $\frac{1}{8}\pi$ . Takto zvolené filtry pokrývají celé spektrum natočení odezev ultrazvuku.

Pro výpočet vektoru příznaků je možné použít různé výstupy filtru – reálnou odezvu, imaginární odezvu nebo velikost (**magnitude**). Nejlepší výsledky poskytuje velikost, byla proto použita. Dále se každý takto získaný obraz rozostří Gaussovským filtrem s poloviční hodnotou  $\sigma$ .

Vlastní extrakce příznakového vektoru pro jeden bod obrazu se provede takto:

1. Filtruj obraz Gaborovým filtrem z dané sady filtrů a získej velikost odezev (magnitude).
2. Vezmi předem zvolené okolí bodu a počítej sumu odezev.
3. Tato suma je jedna hodnota příznakového vektoru.
4. Opakuj bod 1 dokud existují další filtry.

Tímto postupem vzniká 3D histogram. Na obr. 5.3 je tento histogram znázorněn pro dva body obrazu.



Obrázek 5.3: Příklad histogramu sum odezev Gaborova filtru pro různé natočení a různou vlnovou délku. Histogramy jsou různé pro dvě různé oblasti A a B a tyto oblasti je tedy možné odlišit.

Velikost okna, ze kterého se získávají příznaky pro jeden bod v obraze, lze volit různě. Je zřejmé, že velikost okna ovlivňuje podrobnost struktury textury. Čím je velikost větší, tím se více ztrácí detaily textury. To vede ke slévání různých výsledků do jednoho shluku. Naopak, menší okno detekuje podrobnější struktury, a proto je většinou detekováno větší množství shluků.

Tento parametr byl nakonec zvolen konstantní. Okno pro získání texturních příznaků pro jeden bod je vždy ve výsledcích velikosti  $19 \times 19$ px. Takto velké okno poskytuje nejlepší výsledky pro odezvy z použitého ultrazvukového přístroje. V případě použití jiného přístroje, který produkuje jinou strukturu odezev, je tento parametr možný zvolit jinak.

V případě, že okno přesahuje hranici obrazu, je daná hodnota příznakového vektoru doplněna podle rovnice 5.2.


$$x = y + \frac{y \cdot n}{w^2}, \quad (5.2)$$

kde  $y$  je suma bodů, které z daného příznakového okna zasahuje do obrazu,  $n$  je počet bodů mimo obraz a  $w$  je velikost okna. Body, které leží mimo obraz, byly tedy brány jako průměr bodů obrazu.

Bodů v obraze bývá ovšem velké množství. Jedním ze způsobů, jak zredukovat výpočetní náročnost je extrahovat příznakové vektory pouze z některých bodů. Jednotlivá okolí bodů potom mohou být zvolena tak, aby se buď částečně překrývala nebo byla disjunktní. Toto rozhodnutí má pak vliv na způsob vizualizace výsledků celé analýzy. Blíže je tato problematika rozebrána v podkapitole „Vizualizace výsledků“.

## Shlukování

Dalším krokem texturní analýzy je určení podobnosti mezi získanými příznakovými vektory a jejich rozdělení do shluků. Toto zajišťuje metoda shlukování. V práci je použit algoritmus



Obrázek 5.4: Porovnání způsobu vizualizace při texturní analýze.

mean shift, který byl popsán v teoretickém rozboru. Je možné případně využít i jiných, např. K-means nebo GMM (**Gaussian Mixture Models**).


### Vizualizace výsledků

Stejně jako u segmentačních metod, je třeba předat informaci o výsledcích texturní klasifikace uživateli. Oproti segmentačním metodám je k tomu využít jiný přístup. Pro prezentaci se využijí různé barvy v závislosti na tom, do kterého shluku byla daná oblast přiřazena. V prvním způsobu jsou oblasti, ze kterých se získává příznakový vektor, zvolené tak, aby se nepřerývaly. Celá oblast je pak obarvena jednou barvou podle příslušnosti ke konkrétnímu shluku. Tento způsob není ale vhodný k vizualizaci výsledků.

Lepším přístupem je použití překrývajících se oblastí. Každá oblast se v tomto případě také obarví barvou podle příslušnosti ke shluku, ovšem s menší intenzitou. V místech, kde se překrývá více oblastí, je pak výsledný obraz složen z barev těchto oblastí. Vzniká tím plynulý přechod mezi barvami.

Takto získaný obraz je možno navíc přidat do původního obrazu. Tímto způsobem lze získat výsledek, který má nejlepší vypovídací hodnotu z popsanych.

Porovnání těchto tří způsobů je na obr. 5.4.



Obrázek 5.5: Návrh základní obrazovky uživatelského rozhraní.

## 5.5 Návrh aplikace

Vlastní aplikace bude rozdělena do tří částí. První částí budou vlastní metody úprav obrazů implementované pomocí sdílených knihoven. Toto umožní snadnou úpravu stávajících metod a přidávání metod nových. Všechny tyto metody budou mít stejné rozhraní. Dále v textu tyto sdílené knihovny, která každá implementuje nějakou metodu zpracování ultrazvukového obrazu, budou označovány jako pluginy.

Druhá část bude grafické uživatelské rozhraní blíže popsané v následující podkapitole této práce (5.6). Třetí částí je vlastní jádro aplikace, které vše propojí.

Vstupem aplikace budou primárně jednotlivé obrazy z ultrazvuku nahrané ze souboru. Mělo by ovšem být možné načíst i video ze souboru, a z něj vybrat zpracovávaný snímek. Dále by mělo být možné připojit přímo ultrazvukový přístroj.

## 5.6 Návrh uživatelského rozhraní

Nejdůležitější částí aplikace bude schopnost zobrazit výstupy jednotlivých implementovaných metod. Je také důležité mít srovnání s původním obrazem, protože většina postupů při vylepšení obrazu z ultrazvuku sice usnadňuje vizuální diagnostiku, ale může také vést ke špatné interpretaci. Proto je nutné upravený obraz srovnat s původním, aby se riziko špatné diagnózy snížilo.

Základní rozvržení hlavního okna aplikace je uvedeno na obr. 5.5. V základu aplikace bude jednookenní. Aplikace byla navržena tak, aby dodržovala standardní způsob ovládání. Základní funkce ovládání programu, a také jednotlivé pluginy, budou jednak v hlavním menu (v náčrtu pod číslem 5), a také v lištách (angl. **toolbar**, v náčrtu červeně pod číslem 1). Dále bude zobrazen původní (č. 3) a zpracovaný obraz (č. 4). Zelená oblast náčrtu určuje panel s nastavením jednotlivých pluginů (č. 2). Případné stavové informace budou zobrazeny ve spodní stavové liště.

## Kapitola 6

# Implementace

Tato kapitola popisuje způsob implementace daného návrhu. Jsou zde popsány použité externí knihovny. Podkapitola 6.4 se stručně věnuje popisu implementace vlastní aplikace, zejména z pohledu důležitých tříd.

### 6.1 Optimalizace mean shift algoritmu

Existuje několik způsobů, jak algoritmus, jinak velmi výpočetně náročný, optimalizovat. Pokud je použit Gaussův kernel, není třeba pro určení nové pozice bodu procházet všechny zbylé body v prostoru příznaků. V případě, že vzdálenost počítaného bodu  $x$  od jiného bodu  $x_i$  v prostoru je velká, potom  $e^{-(x-x_i)}$  je velmi malé. Tento příspěvek k nové pozici bodu  $x$  je tedy možno zanedbat.

Optimalizace tedy v tomto případě spočívá v tom, že se nová pozice bodů počítá jenom z  $k$  nejbližších sousedů případě se naleznou body do určité vzdálenosti od původního.

Dále se také nabízí použití více vláken. Jednotlivé výpočty nových pozic bodů v prostoru příznaků jsou na sobě nezávislé a je tedy možné výpočet spustit ve více vláknech. Existují i implementace na grafických kartách pomocí technologie CUDA. Ve výsledné aplikaci ale nakonec nebylo využito vícevláknového přístupu.

### 6.2 Použité mean shift implementace

Z počátku byla jako implementace mean shift algoritmu použita metoda FAMS [9], která je volně dostupná z [5]. Je zde možné omezit počet bodů  $k$ , ze kterých se počítá mean shift vektor. Jako šířka pásma je použita vzdálenost  $k$ -tého nejbližšího bodu.

Kromě popsané metody je také využita vlastní implementace, která využívá knihovny flann pro nalezení nejbližších bodů v prostoru. Při praktické zkoušce bylo zjištěno, že pro správnou funkci algoritmu stačí pokud počet bodů  $k$ , který je využit pro spočítání mean shift vektoru, leží mezi  $\frac{1}{100}$  a  $\frac{1}{200}$  z celkového počtu bodů.

Z tohoto počtu se odvíjí i šířka pásma. Ve vlastní implementaci je šířka pásma pro počítaný bod  $x_i$  získána podle následující rovnice:

$$h_{x_i} = 2d_k, \tag{6.1}$$

kde  $d_k$  je vzdálenost nejvzdálenějšího bodu z  $k$  použitých.

Vlastní implementace byla vytvořena zejména kvůli lepší kontrole nad nastavením algoritmu. Také bylo vytvořeno těsnější propojení s aplikací, protože bylo využito datových struktur knihovny OpenCV.

## 6.3 Použité knihovny

### OpenCV

OpenCV [2] je open-source knihovna od společnosti Intel používaná pro zpracování obrazu a počítačové vidění (odtud plyne název Open Source Computer Vision). Primárně je určena pro jazyky C/C++ a Python. Aktuálně je ve verzi 2.2. Knihovna je multiplatformní a tedy je možné ji využít jak na OS Windows, tak GNU/Linux a Mac OS.

Tato knihovna obsahuje několik set funkcí pro zpracování obrazu, vstup a výstup obrazů a videa a také základní multiplatformní grafické uživatelské prostředí.

Více informací o knihovně lze získat, mimo oficiálních stránek projektu, v knize Learning OpenCV [6].

Součástí knihovny OpenCV je i knihovna FLANN. Implementuje metody pro hledání nejbližších sousedů ve vícerozměrném prostoru. Tato knihovna byla využita ve vlastní implementaci Mean Shift algoritmu.

### QT

QT [3] toolkit od společnosti Nokia patří mezi nejrozšířenější multiplatformní knihovny pro tvorbu grafického uživatelského prostředí. Knihovna je primárně určená pro jazyk C/C++, ale je dostupná i pro jiné jazyky, jako je například Python, Perl, Ruby apod. Je dostupná, kromě komerční licence, i v licenci GPL (verze 3) a LGPL (verze 2.1).

Pomocí knihovny QT je napsáno množství aplikací jako například Skype, Google Earth, Opera a mnoho jiných. Je také použit jako základní grafický balík pro prostředí KDE.

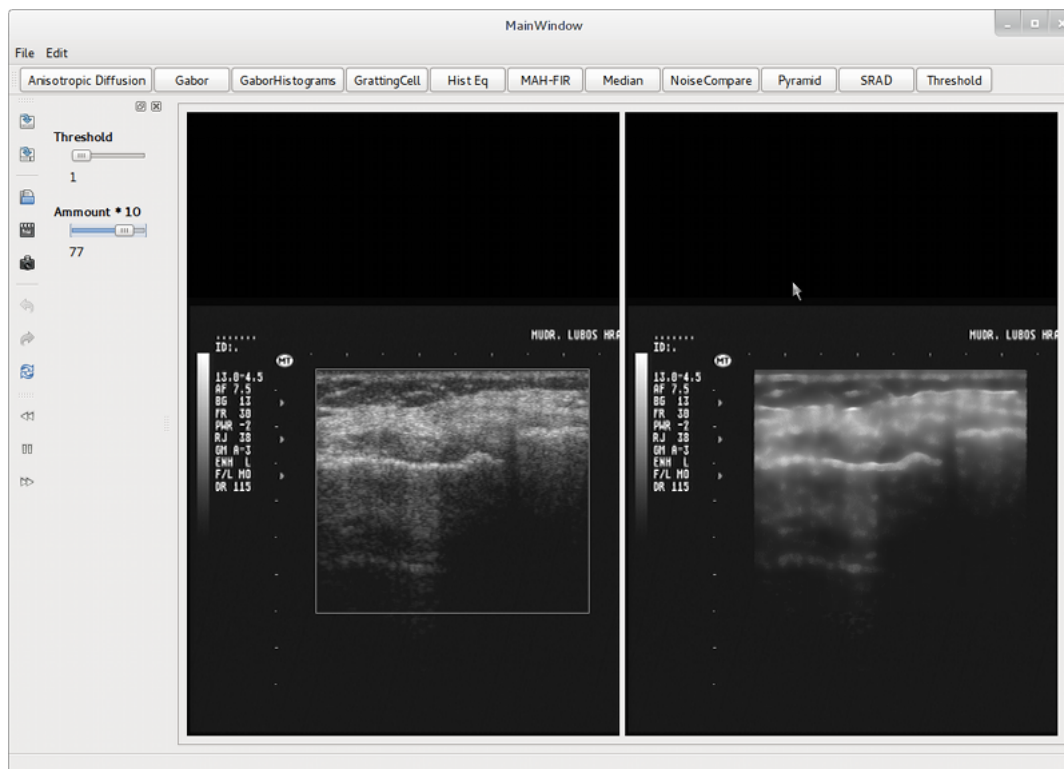
## 6.4 Aplikace

Vlastní aplikace je jednoduchá, napsaná tak, aby dokázala demonstrovat implementované metody. Nalezení a implementování těchto metod bylo ostatně základním cílem práce. Jádro celé aplikace v současné chvíli tvoří několik základních tříd.

Třída `PluginHandler` tvoří základ aplikace. Stará se o načtení pluginů ze sdílených knihoven a jejich spuštění.

Třída `MainWindow` zabezpečuje vytvoření základního okna aplikace a rozhraní vůči uživateli. Obsahuje dvě upravené komponenty, které zajišťují vykreslení původního i upraveného obrazu. Další ze základních tříd je `BasePlugin`, která tvoří rozhraní vůči pluginům. Každý plugin dědí tuto třídu. Z problémů společných pro všechny pluginy implementuje například možnost obarvení původního obrazu podle výsledku segmentace. Dále obsahuje několik virtuálních metod, které vytvářejí vlastní rozhraní. Liší se počtem argumentů (je zde například původní, ničím neupravený obraz, dále již zpracovaný obraz). Výstupem těchto metod je vždy jeden obraz, který reprezentuje výsledek implementované metody. Při tvorbě jednotlivých pluginů je třeba mít na paměti, že obraz může mít definovanou určitou oblast zájmu a je tedy nutné pracovat jenom s touto oblastí.

Poslední z větších tříd v aplikaci je `VideoThread`, která se stará o přehrávání videa. Jako parametr má `CvCaption`, je tedy jedno, jestli původ videa je v souboru nebo je video



Obrázek 6.1: Snímek obrazovky demonstrační aplikace.

získáváno přímo z ultrazvukového přístroje. Tato třída implementuje základní funkcionalitu pro získání obrazu, pozastavení a pokračování v přehrávání apod. Jak již název napovídá, celá tato třída má vyhrazeno vlastní vlákno a neblokuje tedy celou aplikaci.

## Uživatelské rozhraní

Vlastní podobu aplikace je možné vidět na obr. 6.1. Aplikace se drží návrhu představeného v kapitole 5.6. Mezi základní vlastnosti aplikace patří:

- Načtení obrazu ze souboru a uložení výstupu do souboru
- Načtení videa ze souboru, přehraní videa, zpracování jednoho snímku z videa
- Získání obrazu přímo z ultrazvukového přístroje
- Výběr oblastí zájmu
- Kombinování jednotlivých metod

# Kapitola 7

## Výsledky

Tato kapitola se věnuje testování jednotlivých implementovaných metod. V první části je provedeno porovnání jednotlivých algoritmů odstranění šumu. Také je zde test metody klasifikace textur v obraze. Dále jsou popsány výsledky testování na reálných ultrazvukových obrazech. Také je zde v krátkosti popsána aktuální verze demonstrační aplikace.

### 7.1 Odstranění šumu

V této části jsou vyhodnoceny algoritmy odstranění šumu.

V první části byly vybrány oblasti, které tvoří homogenní strukturu a měly by tedy mít stejnou odezvu. V tabulce 7.1 je vidět průměrná hodnota pixelů a směrodatná odchylka původního obrazu a také hodnoty, které dosáhly jednotlivé metody.

Tato tabulka dokládá, že nejlépe redukuje šum anizotropní difuze a zejména její modifikace v podobě SRAD. Je zde také vidět, že MAH-FIR filtr poměrně hodně zvyšuje průměrný jas pixelů.

Druhé základní kritérium metod pro odstranění šumu se týká zachování hran v obraze. Toho se tedy týkal druhý experiment. Originální uměle vytvořený obraz  $I$ , do kterého byl přidán šum s poměrem k signálu (SNR, dle rovnice 7.1) 5.4997 dB. Zašuměný obraz je v rovnici označen  $I_{noise}$ .

$$SNR = 10 \log_{10} \left( \frac{I^2}{(I - I_{noise})^2} \right) \quad (7.1)$$

V dalším kroku byl šum odstraněn jednotlivými testovanými metodami. Výstupy těchto metod společně s původním a uměle zašuměným obrazem jsou na obr. 7.1.

Dále byly v těchto výsledných obrazech nalezeny hrany. K tomu byl využit cannyho hranový detektor [17]. Výsledek na původním, nezašuměném obraze byl potom použit jako ideální výsledek.

Vlastní kritérium správně detekované hrany pak bylo zvoleno podle vzorce 7.2 navrženého v [19]:

$$R = \frac{1}{I_N} \sum_{i=1}^{I_A} \frac{1}{1 + ad^2}, \quad (7.2)$$

kde  $I_A$  je obraz výstupu jedné metody s nalezenými hranami,  $I$  je obraz s ideálně detekovanými hranami,  $I_N = \max\{I, I_A\}$ ,  $d$  je euklidovská vzdálenost od mezi detekovaným bodem hrany a ideálním bodem a  $a$  je konstanta  $\frac{1}{9}$ .




Metoda	Průměr	Směrodatná odchylka
Původní obraz	157,034	19,9469
Medián	156,704	14,2337
MAH-FIR	160,987	12,6625
AD	157,170	10,1391
SRAD	157,240	7,2786

(a) Oblast 1

Metoda	Průměr	Směrodatná odchylka
Původní obraz	46,1188	10,7679
Medián	45,952	9,3897
MAH-FIR	50,1888	9,5432
AD	46,1212	8,9307
SRAD	46,1516	9,2034

(b) Oblast 2

Tabulka 7.1: Výsledky metod odstranění šumu.



Obrázek 7.1: Výsledky jednotlivých metod odstranění šumu na umělém obraze.

Metoda	FOM
Zašuměný obraz	0,5220
Medián	0,5383
MAH-FIR	0,5316
AD	0,6688
SRAD	0,9023

Tabulka 7.2: Výsledky testu zachování hran.

Výstupem této metody je číslo v rozsahu 0–1, kde 1 znamená absolutní shodu mezi ideálními hranami a detekovanými hranami.

Výsledek pro jednotlivé metody je v tabulce 7.2. Je zde patrné, že nejlepší výsledek poskytuje metoda SRAD. Druhým v pořadí je anizotropní difuze. Naopak MAH-FIR filtr má podobný výsledek jako mediánový filtr. Obě hodnoty se velmi blíží původnímu zašuměnému obrazu.

## 7.2 Texturní analýza

V rámci testu texturní analýzy byl vytvořen obraz (obr. 7.2a) skládající se ze šesti oblastí. Každou tuto oblast tvoří homogenní struktura získaná z reálných ultrazvukových obrazů. Každá tato oblast by tedy měla spadat do jednoho shluku.

Dále bude popsán vliv jednotlivých parametrů této metody na výsledek. Byl proveden také test přesnosti detekce.

### Vliv šířky okna

Jak již bylo zmíněno, šířka okna, ze kterého se získávají texturní příznaky pro jeden bod, ovlivňuje výsledek klasifikace. Čím je okno menší, tím více je analýza ovlivněna malými lokálními změnami, které ovšem nemusí znamenat jinou texturu. Příliš velké okno naopak vede ke splynutí více rozdílných oblastí do jedné. Rozdíl je možné vidět na obr. 7.2. Jsou zde porovnány zpracované snímky s velikostí texturního okna  $13 \times 13$ px,  $19 \times 19$ px a  $37 \times 37$ px.

Menší okno obecně způsobuje větší počet detekovaných shluků. Naopak, větší okno v normálních obrazech způsobí menší počet shluků. V testovacím snímku ovšem oba extrémy způsobily větší počet detekovaných shluků. To je dáno špatným poměrem mezi velikostí okna a velikostí jednotlivých oblastí.

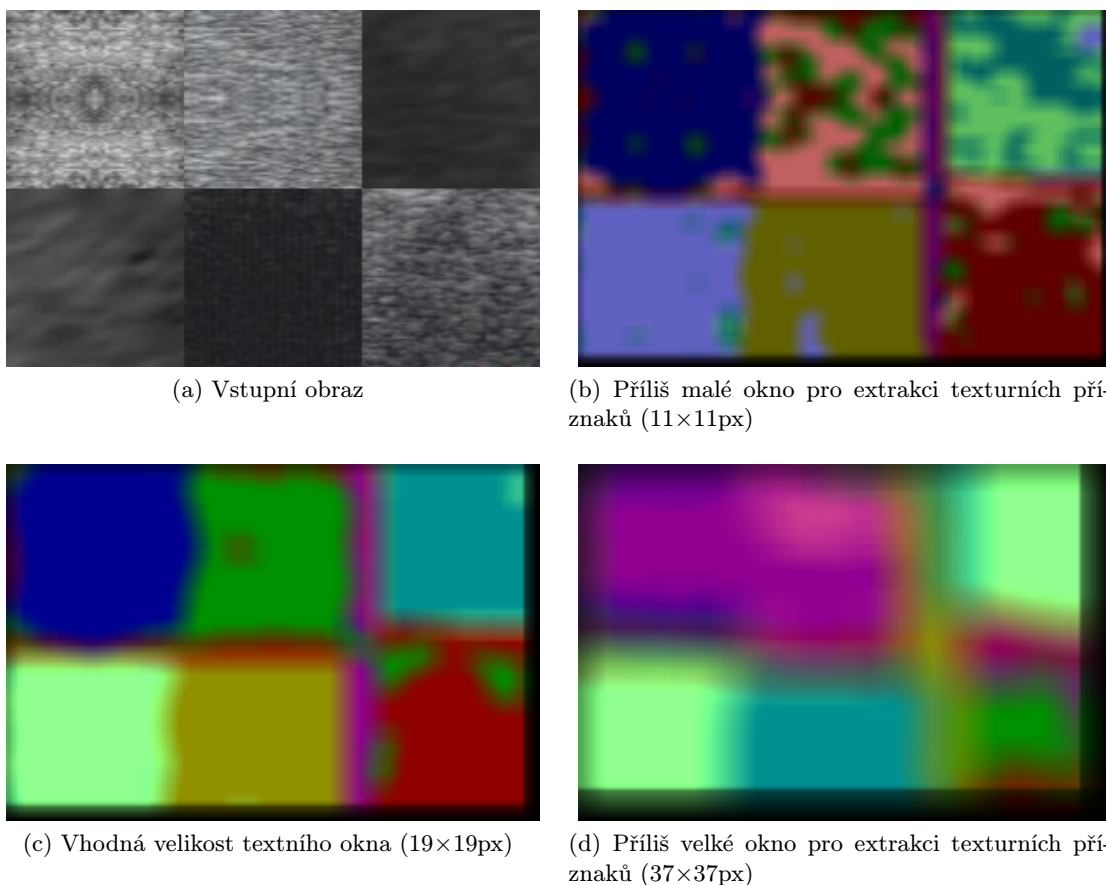
Pro použitý ultrazvukový přístroj tedy nejlepší výsledky poskytuje velikost okna mezi  $16 \times 16$ px a  $21 \times 21$ px.

### Použité Gaborovy filtry

Pro extrakci texturních příznaků bylo využito filtrování sadou Gaborových filtrů. Lišily se různou vlnovou délkou a natočením. Nejlepší výsledky poskytovala kombinace vlnových délek 2px, 3px a 4px a natočení  $\langle 0 - \frac{7}{8}\pi \rangle$  s krokem  $\frac{1}{8}\pi$  (obr. 7.2c).

V závislosti na použitém ultrazvukovém přístroji je možné, že bude vyhovovat jiná kombinace těchto filtrů. Je také zřejmé, že čím méně je použito filtrů, tím menší je příznakový vektor a tím rychleji poskytne metoda výsledek.

Výstupy pro jiné kombinace, neposkytující tak dobré výsledky, jsou uvedeny v příloze.



Obrázek 7.2: Porovnání různě velkých oken pro extrakci texturních příznaků.

### Přesnost detekce

Byl také proveden test správnosti a přesnosti detekce. Metoda texturní klasifikace byla nastavena podle předem vyhodnocených parametrů.

Pro test přesnosti byl použit výsledek texturní analýzy se správně zvoleným oknem pro extrakci texturních příznaků (obr. 7.2c). Je patrné, že metoda relativně přesně detekuje struktury uprostřed oblastí. Naopak, detekce na rozhraních oblastí v některých případech selhává. Tmavší okraj obrazu je způsoben tím, že se na celkovém jasu podílí méně oken. V reálných ultrazvukových snímcích bývá většinou objekt zájmu uprostřed a krajní body nejsou pro zlepšení čitelnosti obrazu důležité.

Výsledky správnosti klasifikace textur jsou také shrnuty v tabulce 7.3. Je zde vidět, že správně bylo detekováno 83 % bodů. Nesprávně jsou detekovány některé hrany mezi oblastmi.

Celkově bylo detekováno 7 shluků. Rozhraní mezi dvěma značně odlišnými oblastmi bylo detekováno jako jiný shluk. Pokud jsou oblasti podobnější, je přechod plynulejší. V reálných datech tato situace nastává téměř výhradně.

### 7.3 Testování na reálných ultrazvukových obrazech

Kromě testovacích snímků získaných z internetu (zejména [20]), byly získány i ultrazvukové obrazy pacientů společně s jejich diagnózami. Je tedy možné srovnat výsledky jednotlivých metod s prokázanými diagnózami.

Jednotlivé výsledné obrazy je těžké hodnotit nějakým objektivním kritériem. Přestože proběhlo ve spolupráci s lékařem, specialistou, jedná se pouze o subjektivní hodnocení zlepšení čitelnosti obrazu podložené znalostí diagnózy.

#### Ledvinové metastáze

První z testovacích obrazů (obr. 7.3) ukazuje ultrazvukový obraz ledvin s několika metastázemi rakoviny slinivky břišní. Obraz byl převzat z [20].

Z obrazu byla nejprve vybrána oblast zájmu (obr. 7.3b). V této oblasti dominují dvě velké, ohraničené metastáze, které jsou vyznačeny červenou barvou. Žluté oblasti jsou artefakty vzniklé za oběma metastázemi. V okolí obou metastáz může docházet k prorůstání do okolí. Odhalení tohoto jevu bylo smyslem použití implementovaných metod. Prorůstání je většinou charakterizováno květákovitou strukturou okolí, která má podobnou charakteristiku jako je uvnitř metastáz.

Obr. 7.3c ukazuje obarvený obraz podle pyramidové segmentace. V obou oblastech, které byly následně identifikovány jako velmi pravděpodobně prorůstající metastáze, je vidět částečná podoba s vnitřkem metastáze. V tomto způsobu vizualizace je ovšem špatně patrná.

Další snímek (obr. 7.3d ukazuje obraz s ekvalizovaným histogramem. Jelikož se zvýšil kontrast, je více patrný tvar struktur.

Obr. 7.3e ukazuje vizualizaci po texturní klasifikaci. Na obraze jsou zvýrazněny dvě oblasti, kde podle výsledku této metody pravděpodobně dochází k prorůstání do okolní tkáně. Větší oblast má charakteristickou květákovitou strukturu.

#### Nezhoubný novotvar v dolní končetině

Další testovací snímek je na obr. 7.4. Tento snímek byl získán od externího konzultanta i s diagnózou pacienta. Jedná se o nezhoubné ložisko uvnitř hypoechogenní (místo se slabší odezvou při ultrazvukovém vyšetření, např. tekutina), dobře ohraničené a neprorůstající do okolí. Červená místa v původním obraze jsou výsledkem barvené Dopplerovské analýzy. Vlastní útvar je v původním obraze ohraničen čtyřmi oranžovými body.


Ohraničení je velmi dobře patrné i ze zpracovaných snímků. Obr. 7.4f ukazuje texturní analýzu obrazu, který byl předzpracován pomocí SRAD. Je vidět jasné oddělení červené barvy, která vyplňuje vlastní útvar a okolní tkáně, která je vyznačena modře.

Celkový počet bodů	6600
Správně detekováno	5477
Procent	83 %


Tabulka 7.3: Výsledky testu přesnosti klasifikace textur.




(a) Původní obraz




(b) Oblast zájmu. Červeně jsou označeny metastázy, žlutě artefakty. U metastáz může docházet k jejich prorůstání do okolí.





(c) Obarveno podle výsledku pyramidové segmentace .



(d) Ekvalizace histogramu




(e) Výsledek po texturní klasifikaci.




Obrázek 7.3: Ultrazvukový obraz ledvin s několika metastázemi. Převzato z [20].



(a) Původní obraz




(b) Šum odstraněn anizotropní difuzí




(c) Šum odstraněn pomocí SRAD.



(d) Ekvalizace histogramu




(e) Pyramidová segmentace




(f) Texturní klasifikace předzpracovaná pomocí SRAD

Obrázek 7.4: Ultrazvukový obraz nezhoubného útvaru v dolní končetině.







(a) Původní obraz



(b) Zpracovaný anizotropní difuzí společně s ekvalizací histogramu.



(c) Zpracovaný pyramidovou segmentací společně s ekvalizací histogramu.



(d) Klasifikace textur společně s ekvalizací histogramu.

Obrázek 7.5: Ultrazvukový obraz liposarkomu.

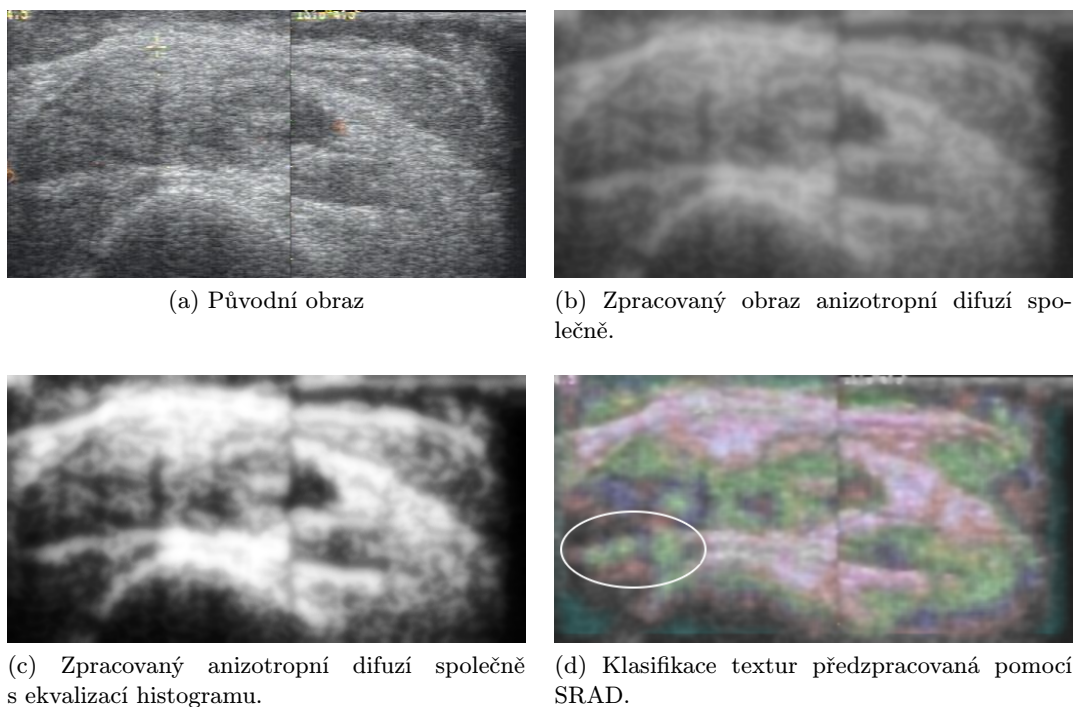
## Liposarkom

Obr. 7.5 ukazuje ultrazvukový obraz liposarkomu. Liposarkom je zhoubný nádor tukové tkáně, v tomto případě se nachází v dolní končetině. Vlastní nádor je v původním obraze opět vyznačen dvěma oranžovými body.

Původní obraz má velmi špatný kontrast. Proto je pro tento typ obrazu vhodné zvýšení kontrastu pomocí ekvalizace histogramu. V kombinaci s anizotropní difuzí pro odstranění šumu je vidět na obr. 7.5b. Metoda ekvalizace histogramu byla použita i v kombinaci s pyramidovou segmentací 7.5c, kde je opět vidět lepší ohraničení vlastního nádoru. Ovšem texturní analýze (obr. 7.5d) v tomto případě neposkytla žádný kvalitní výsledek.

## Desmoid

Dále následuje více snímků od jednoho pacienta získané v průběhu delší doby. U tohoto pacienta se jedná o nezhoubný nádor dolní končetiny, nevytvářející metastázy, který je ovšem lokálně agresivní. Na obr. 7.6 je ultrazvukový snímek tohoto nádoru v době pokročilého léčení. Snímek je složen ze dvou. Toto je způsobeno tím, že nádor je větší, než je schopen použitý ultrazvuk zobrazit.



Obrázek 7.6: Ultrazvukový obraz desmoidu.

Nádor má difuzní povahu, lze jen obtížně stanovit okraje. Je to způsobeno také tím, že nádor je již delší dobu léčen a postupně ustupuje.

Vlastní snímek má malý kontrast, což je ještě zvýrazněno po odstranění šumu anizotropní difuzí (obr. 7.6b). Na obr. 7.6d je snímek zpracován texturní klasifikací. Jsou zde vidět široké okraje, fialové až růžové barvy, kde je jen obtížné říct, kde končí nádor a začíná zdravá tkáň. Ve vyznačené oblasti je ale jasně patrný segment stejné barvy, jako se objevuje uvnitř nádoru a zde se tedy jedná o tkáň s podobnou odezvou.

Stejný útvar je také na obr. 7.7. Opět se jedná o obraz s velmi nízkým kontrastem, což lze zlepšit ekvalizováním histogramu.


Výsledek analýzy textury opět ukazuje, že přesné okraje tohoto útvaru lze jen obtížně určit.

### Artróza kolenního kloubu


Na obr. 7.8 je vidět porovnání kolene s artrózou se zdravým kolenem. Je zde zdůrazněn povrch kosti, pod kterým se již nachází ultrazvukový stín. V tomto stínu ovšem vznikají artefakty, tedy odezvy, které tam nemají být.

V artrotickém koleni je vidět nepravidelná, zvlněná struktura povrchu kosti. Oproti tomu má povrch kosti zdravého kolene rovný hladký povrch.







(a) Původní obraz



(b) Zpracováno metodou anizotropní difuze.




(c) Zpracováno metodou anizotropní difuze s ekvalizovaným histogramem




(d) Zpracováno metodou klasifikace textur předzpracovanou pomocí anizotropní difuzí.


Obrázek 7.7: Další ultrazvukový obraz desmoidu.




(a) Ultrazvukový obraz artrotického kolene.



(b) Obraz upraven metodou SRAD s doostřením pomocí unsharp mask



(c) Ultrazvukový obraz zdravého kolene.



(d) Obraz upraven metodou anizotropní difuze s doostřením pomocí unsharp mask.

Obrázek 7.8: Porovnání artrotického a zdravého kolene na ultrazvukových snímcích.

## Kapitola 8

# Závěr

Tato práce se zabývala nalezením takových metod zpracování obrazu, které by mohly být využity pro vylepšení obrazu z ultrazvuku pro zajištění přesnější diagnostiky v lékařství. Bylo diskutováno několik možných metod (více v kapitole 4).

Z nalezených metod bylo několik implementováno. Jedná se zejména o algoritmy odstranění šumu, jakými jsou například MAH-FIR filtr, anizotropní difuze a SRAD. Dále byla implementována metoda klasifikace oblastí v obraze na základě textury. Kromě výše zmíněných pokročilých metod zpracování ultrazvukového obrazu bylo také přidáno několik základních, ale vcelku účinných, metod.

Pro účely testování a zjištění vhodnosti jednotlivých metod byla implementována jednoduchá testovací aplikace. Tato aplikace dovoluje použití kombinace několika metod na vybraném obraze. Vstupní obraz lze získat buď ze souboru nebo z videosekvence, nebo je získán přímým připojením ultrazvukového přístroje.

Velká část práce byla věnována testování jednotlivých metod. V první části bylo provedeno srovnání metod odstranění šumu podle dvou kritérií. Prvním byla vlastní schopnost odstranění šumu při zachování stejného jasů obrazu. To bylo zjišťováno pro vybrané homogenní oblasti v reálných ultrazvukových obrazech. Byl zjištěn průměrný jas a směrodatná odchylka jasů v původním obraze. Dále byl obraz filtrován jednotlivými metodami a porovnány průměrné jasy a odchylky ve zpracovaných obrazech. Nejlépe si v tomto testu vedly metody anizotropní difuze a její modifikace SRAD.

Druhý test spočíval v zachování hran v obraze. Byl vytvořen umělý obraz, do kterého byl poté vnesen šum s danými parametry. Po odstranění šumu pomocí jednotlivých metod bylo provedeno srovnání podle popsané metodiky. Nejlépe byla opět hodnocena dvojice anizotropní difuze a SRAD. V obou testech naopak nedopadla dobře metoda MAH-FIR.

Dále byly ukázány výsledky metody texturní klasifikace. Tato metoda může mít velkou hodnotu zejména při určení ohraničení různých objektů v ultrazvukových snímcích. Zejména se jedná o určení hranic různých nádorů a případného prorůstání do okolní tkáně. Na tato místa se potom může lékař více zaměřit.

Další část testování spočívala v subjektivní snaze vylepšit reálné ultrazvukové obrazy pro usnadnění vizuální diagnostiky. Pro tento test bylo získáno několik snímků pacientů společně s přesnými diagnózami. Toto usnadnilo výsledné zhodnocení.

V dalším pokračování se lze zaměřit i na jiné metody, které nebyly implementovány. Dále by také měly jednotlivé metody projít optimalizací. Zejména texturní analýza by se dala proti současné implementaci optimalizovat. Navíc je tato metoda vhodná i pro paralelizaci a to i na GPU.

Aplikace implementována v rámci této práce je velmi jednoduchá. Dobře posloužila pro testování, ale v reálném nasazení by byla potřeba aplikace komplexnější, zohledňující všechny potřeby vyšetřujícího lékaře. Naprogramování takové aplikace by také mělo být součástí možné navazující práce.

# Literatura

- [1] Lab. De Procesado De Imagen: UsimagTool Software. [online], naposledy navštíveno 24. května 2011.  
URL <http://www.lpi.tel.uva.es/usimagtool/>
- [2] OpenCV wiki. [online], naposledy navštíveno 24. května 2011.  
URL <http://opencv.willowgarage.com/wiki/>
- [3] Qt - A cross-platform application and UI framework. [online], naposledy navštíveno 24. května 2011.  
URL <http://qt.nokia.com/>
- [4] Antony, J.: Ultrasound image gallery. [online], naposledy navštíveno 24. května 2011.  
URL <http://www.ultrasound-images.com/>
- [5] B. Georgescu, P. M., I. Shimshoni: FAMS. [online], naposledy navštíveno 24. května 2011.  
URL <http://coewww.rutgers.edu/riul/research/code/AMS/>
- [6] Bradski, G.; Kaehler, A.: *Learning OpenCV: Computer Vision with the OpenCV Library*. Cambridge, MA: O'Reilly, 2008.
- [7] Comaniciu, D.; Meer, P.: Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on pattern analysis and machine intelligence*, 2002: s. 603–619, ISSN 0162-8828.
- [8] Deng, Y.; Huang, H.: Ultrasound Image Segmentation Based on the Anisotropic Diffusion Filtering. In *Bioinformatics and Biomedical Engineering (iCBBE), 2010 4th International Conference on*, IEEE, 2010, ISSN 2151-7614, s. 1–3.
- [9] Georgescu, B.; Shimshoni, I.; Meer, P.: Mean shift based clustering in high dimensions: A texture classification example. In *Computer Vision, 2003. Proceedings. Ninth IEEE International Conference on*, IEEE, 2008, ISBN 0769519504, s. 456–463.
- [10] Hrazdíra, I.: Úvod do ultrasonografie – část I. Principy ultrazvukových diagnostických metod a způsoby jejich využití. [online], naposledy navštíveno 24. května 2011.  
URL [http://www.med.muni.cz/dokumenty/pdf/uvod\\_do\\_ultrasonografie1.pdf](http://www.med.muni.cz/dokumenty/pdf/uvod_do_ultrasonografie1.pdf)
- [11] Hrazdíra, L.: *Možnosti 3D ultrazvukového vyšetření a prostorových rekonstrukcí pohybového aparátu*. Paido, Brno, 2004.
- [12] L. J. Morales-Mendoza, Y. S. S.; Ibarra-Manzano, O. G.: Enhancing Ultrasound Images Using Hybrid FIR Structures. In *Image Processing*, InTech, 2009, ISBN

978-953-307-026-1.

URL <http://www.intechopen.com/articles/show/title/enhancing-ultrasound-images-using-hybrid-fir-structures>

- [13] Loupas, T.; McDicken, W.; Allan, P.: An adaptive weighted median filter for speckle suppression in medical ultrasonic images. *Circuits and Systems, IEEE Transactions on*, ročník 36, č. 1, 1989: s. 129 –135, ISSN 0098-4094.
- [14] Michailovich, O.; Tannenbaum, A.: Despeckling of medical ultrasound images. *Ultrasonics, Ferroelectrics and Frequency Control, IEEE Transactions on*, ročník 53, č. 1, 2006: s. 64 –78, ISSN 0885-3010.
- [15] Mohamed, M.; Abdel-Galil, T.; El-saadany, E.; aj.: Prostate cancer diagnosis based on gabor filter texture segmentation of ultrasound image. In *Electrical and Computer Engineering, 2003. IEEE CCECE 2003. Canadian Conference on*, ročník 3, IEEE, 2003, ISBN 0780377818, ISSN 0840-7789, s. 1485–1488.
- [16] Morales-Mendoza, L.; Shmaliy, Y.; Ibarra-Manzano, O.; aj.: Moving Average Hybrid FIR Filter in Ultrasound Image Processing. In *Electronics, Communications and Computers, 2008. CONIELECOMP 2008, 18th International Conference on*, 2008, s. 160 –164.
- [17] Nixon, M.; Aguado, A. S.: *Feature Extraction & Image Processing, Second Edition*. Academic Press, 2008, ISBN 0123725380.
- [18] Perona, P.; Malik, J.: Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, ročník 12, č. 7, 1990: s. 629–639, ISSN 0162-8828.
- [19] Pratt, W. K.: *Digital Image Processing*. Wiley, New York, třetí vydání, 2001.
- [20] radRounds: radRounds Radiology Network! [online], naposledy navštíveno 24. května 2011.  
URL <http://www.radrounds.com/>
- [21] Sonka, M.; Hlavac, V.; Boyle, R.: Image processing, analysis, and machine vision second edition. *International Thomson*, 1999.
- [22] Wikipedia: Histogram equalization. [online], naposledy navštíveno 24. května 2011.  
URL [http://en.wikipedia.org/wiki/Histogram\\_equalization](http://en.wikipedia.org/wiki/Histogram_equalization)
- [23] Xie, J.; Jiang, Y.; Tsui, H.: Segmentation of kidney from ultrasound images based on texture and shape priors. *Medical Imaging, IEEE Transactions on*, ročník 24, č. 1, 2004: s. 45–57, ISSN 0278-0062.
- [24] Yang, P.; Basir, O.: Adaptive weighted median filter using local entropy for ultrasonic image denoising. In *Image and Signal Processing and Analysis, 2003. ISPA 2003. Proceedings of the 3rd International Symposium on*, ročník 2, 2003, ISSN 1330-1012, s. 799 – 803.
- [25] Yu, Y.; Acton, S.: Speckle reducing anisotropic diffusion. *Image Processing, IEEE Transactions on*, ročník 11, č. 11, 2002: s. 1260–1270, ISSN 1057-7149.
- [26] Zemčík, P.; Španěl, M.: *Studijní opora předmětu ZPO*. FIT VUT v Brně, 2006.

# Příloha A


## Obsah CD

K technické zprávě bylo přidáno i CD/DVD s následujícím obsahem:

- /doc/ – Dokumentace k aplikaci vytvořená v programu doxygen
- /plakat/ – Plakát vytvořený k diplomové práci
- /result/ – Výsledné obrazy
- /tex/ – Tato technická zpráva včetně zdrojových kódů v L<sup>A</sup>T<sub>E</sub>Xu
- /trunk/data – Testovací data
- /trunk/plugins – Přeložené jednotlivé pluginy ve formě sdílených knihoven
- /trunk/resources – Použité ikony v aplikaci
- /trunk/settings – Nastavení aplikace
- /trunk/src – Zdrojové kódy aplikace
- /trunk/UIVETool – Vlastní přeložená aplikace

## Příloha B

## Plakát



Obrázek B.1: Náhled plakátu vytvořeného k diplomové práci.



## Příloha C

### Výsledky texturní klasifikace pro různé sady Gaborových filtrů




(a)  $\lambda=4\text{px}, 5\text{px}, 6\text{px}$



(b)  $\lambda=2\text{px}, 3\text{px}$




(c)  $\lambda=3\text{px}, 4\text{px}$



(d)  $\lambda=3\text{px}, 5\text{px}$




(e)  $\theta = \langle 0 - \frac{6}{7}\pi \rangle$  s krokem  $\frac{1}{7}\pi$ .



(f)  $\theta = \langle 0 - \frac{5}{6}\pi \rangle$  s krokem  $\frac{1}{6}\pi$ .



(g)  $\theta = \langle 0 - \frac{4}{5}\pi \rangle$  s krokem  $\frac{1}{5}\pi$ .



(h)  $\theta = \langle 0 - \frac{3}{4}\pi \rangle$  s krokem  $\frac{1}{4}\pi$ .



(i)  $\theta = \langle \frac{1}{8}\pi - \frac{7}{8}\pi \rangle$  s krokem  $\frac{2}{8}\pi$ .



(j)  $\theta = \langle 0 - \frac{7}{8}\pi \rangle$  s krokem  $\frac{2}{8}\pi$ .

Obrázek C.1: Výsledky texturní klasifikace pro různě nastavené parametry  $\lambda$  a  $\theta$